

Asiakasmäärän mittaaminen



Ammattikorkeakoulututkinnon opinnäytetyö
Tieto- ja viestintätekniikan koulutus, insinööri (AMK)

Riihimäki, kevät 2022

Sami Vänttinen

Tieto- ja viestintäteknikka

Tekijä Sami Vänttinen

Työn nimi Asiakasmäärän mittaaminen

Ohjaaja Timo Karppinen

Tiivistelmä

Vuosi 2022

Opinnäytetyön tavoitteena oli tutkia erilaisia vaihtoehtoja kaupan asiakasmäärien mittaukseen sekä rakentaa konenäköön perustuva laite tuottamaan asiakasmäärädataa IoT Analytics Finlandin analytiikkapalveluiden tueksi.

Kauppojen asiakasmäärät mitataan tyypillisesti ulko-ovilta, mikä mahdollistaa yleisen ymmärryksen asiakasmäärästä, sekä asiakasmäärästä kulkuaukoilta. Kun halutaan parempi ymmärrys asiakkaiden ostoskäyttäytymisestä ja liiketilojen käytöstä, siihen tarvitaan mittaustapoja, joilla voidaan kattaa suurempia alueita. Nykypäivänä konenäkösovellukset ovat kustannustehokas tapa toteuttaa tämä mittaus.

Työssä testattiin erilaisia konenäköalgoritmeja ja kameroita, joista voi valita tarkoitukseen soveltuvat mallit, sekä verkkolaitteet, joiden avulla data voidaan tarvittaessa siirtää haluttuun palveluun. Laskentayksikkönä käytettiin Raspberry Pi4 -tietokonetta, joka on kelvoinen laite protoiluun, mutta jää laskentatehossa esimerkiksi NVIDIAN laitteille, jotka on kehitetty konenäkösovelluksiin.

Vaativammasta laskentatehosta huolimatta Raspberry Pi4 oli riittävän tehokas suoriutumaan henkilömäärämittauksesta, sillä tiedon päivitystarve on harva. Rakennetun laitteen tarkkuus yllätti positiivisesti, sillä laite pystyi tunnistamaan henkilöt, vaikka he olivatkin suurelta osin katveessa.

Työssä käytetyn kokoonpanon avulla voidaan projektinomaisesti tutkia henkilömääriä hyvin pienellä investoinnilla ja mahdollinen laitteen monistaminen tapahtuu SD-muistin kopiolla. Laitteen koko on myös huomaamattoman pieni. Toki laite on harraste- tai protoilutasoa, mutta toiminnallisuus on sama kuin vartavasten käyttöön suunnitelluilla laitteilla.

Avainsanat konenäkö, sulautettu tietotekniikka, toimitilat

Sivut 45 sivua

The aim of the thesis was to study different alternatives for measuring the number of customers in retail and to build a device based on computer vision to produce customer volume data to support IoT Analytics Finland's analytical services. IoT Analytics Finland is the commissioner of the thesis.

In the retail industry, the number of customers is typically measured from the front doors, which allows a general understanding of the customer traffic, as well as the quantities from the access openings. When a better understanding of customers' shopping behavior and the use of retail space is required, measurement methods are needed to cover larger areas. In the 2020s, machine vision applications are a cost-effective way to implement this measurement.

Various machine vision algorithms and cameras were tested in the thesis, from which suitable models can be selected, as well as network devices that can be used to transfer data to the desired service, if necessary. The Raspberry Pi4 computer was used as the computing unit, which is a valid device for prototyping, but lagging in computing power for NVIDIA devices, which are developed for machine vision applications, for example.

Despite the modest computing power, the Raspberry Pi4 was powerful enough to perform a headcount measurement when the need to update data is rare. The accuracy of the built device was a positive surprise, as the device was able to identify people even though they were largely obscured.

With the configuration used in the work, the number of people can be studied project-like with a very small investment and the possible duplication of the device would take place with a copy of the SD memory. The size of the device is also inconspicuously small. The device is suitable for prototyping, but the functionality is the same as devices designed for use.

Keywords Computer vision, ubiquitous computing, business premises.

Pages 45 pages

Sisällys

1	Johdanto	1
2	Henkilömäärien mittaustavat	2
2.1	Ihmislaskureiden kehitys	2
2.2	Infrapunasädelaskurit	2
2.3	Lämpölaskurit	3
2.4	2D-henkilölaskuri	4
2.5	3D-henkilölaskurit	5
2.5.1	Wi-Fi laskurit	7
2.6	Konenäköön perustuvat laskurit	8
2.7	Johtopäätökset	8
3	Konenäkö	9
3.1	Konenäön historia	10
3.2	Konenäön tulevaisuus	10
3.3	Konenäön sovelluksia	10
3.3.1	Laadunvarmistus	11
3.3.2	Toimitusketjun ohjaus	11
3.3.3	Tuottavuuden kehitys tuotannossa	11
4	Soveltuvat laitteet	12
4.1	Laskentayksiköt	13
4.1.1	Jetson Nano	13
4.1.2	Jetson Xavier	15
4.1.3	Raspberry Pi4 model B	17
4.1.4	Raspberry Pi:n suorituskyvyn kehitys	19
4.1.5	Suorituskykyvertailu Raspberry Pi 4 vs. Jetson Nano	20
4.1.6	Speedometer 2.0 selaimen nopeustesti	21
4.1.7	Muistin kaistanleveys	22
4.1.8	USB muistin läpimeno	23
4.1.9	Virrankulutus	23
4.2	Kamerat	25
4.2.1	Logitech C920 webkamera	25

4.2.2	Raspberry Pi kamerat	26
4.2.3	Dahua IP-kamera	27
4.3	Verkkolaitteet	30
4.3.1	Dahua PoE kytkin.....	30
4.3.2	Teltonika RUT240 reititin	31
5	Toteutus.....	33
5.1	Käyttöjärjestelmän asennus.....	33
5.2	Hahmontunnistusalgoritmit.....	36
5.2.1	MobileNet-V1 SSD arkkitehtuuri.....	37
5.2.2	YOLO v5	38
5.2.3	COCO dataset	41
5.3	Laitteen testaus.....	41
6	Yhteenveto	42
	Lähteet.....	43

1 Johdanto

Kaupan tunnuslukuihin kuuluu olennaisena osana asiakasmäärät. Tämä on hyvä mittari kokonaisuuden ymmärtämiseen sekä kehityksen seuraamiseen. Myynnin kehittäminen vaatii kuitenkin tarkempaa tietoa tilojen käytön optimoimiseksi, sekä tuotteiden optimaaliseen sijoitteluun. Kun mittaus suoritetaan hyllyväleittäin ja ohi kulkevien asiakkaiden määrään yhdistetään myyntidata, saadaan mitattua tuotteille avainmittari capture rate.

Asiakaskokemuksen kannalta kaupan kassojen sujuva toiminta on tärkeä. Asiakasmäärien mittausta voidaan suorittaa myös kassajonojen pituudelle, josta voidaan arvioida tai mitata jonotusajat. Kassajonojen mittaus mahdollistaa oikean henkilöstön mitoituksen kassoille ja siten parantaa asiakastytyvyyttä.

Toimiva asiakasmäärien mittaus mahdollistaa kauppakeskuksissa tilojen käyttöasteen mittaamisen ja mahdolliset muutokset nähdään faktaperusteisesti.

Tyypillisesti mittaus on suoritettu sisäänkäyntien yhteydessä jolloin saadaan tieto asiakasmääristä liiketilassa, mutta asiakkaiden ostoskäyttäytyminen jää ymmärtämättä. Myös liiketilojen tilojen hyödyntämisen ymmärtäminen vaatii alueellisen mittauksen. Tällainen data voidaan esittää esimerkiksi heatmap-muodossa aikaperusteisesti ja tuotemyynnin osalta capture rate -mittarilla, joka tarkoittaa asiakasmäärää, joka on nähnyt tuotteen, jaettuna tuotteen ostaneiden asiakasmäärällä.

Työssä on tavoitteena luoda konenäköön perustuva ohjelmisto ja laitteisto keräämään asiakasmäärädataa IoT-Analyticsin analytiikkapalveluiden tueksi. Palvelu on uusi ja vielä hyvin vähän käytössä, joten sovellus tulee olemaan ainakin alkuun kokeiluluonteinen. Laitteiston avulla voidaan mitata asiakasmäärät halutuista tiloista.

Työn tilaajana toimii IoT-Analytics Finland Oy.

2 Henkilömäärien mittaustavat

Henkilömäärien mittaukseen on ajan saatossa kehitetty erilaisia mittausmenetelmiä kuten kääntöportit, infrapuna portit, lämpökuva, Wifi seuranta ja konenäkö. Useimmissa näistä sovelluksista on toiminnallisena vaatimuksena kulunhallinta esim. tilaan käynti määrättyjä kulkuväyliä käyttäen.

2.1 Ihmislaskureiden kehitys


Ihmislaskureita on käytetty viimeisen kahden vuosikymmenen ajan. Tuona aikana laskureiden tekniikka on parantunut huomattavasti vuosien saatossa. Jokaisen uuden sukupolven ominaisuudet voittavat edeltäjänsä puutteet ja epätarkkuudet. (FootFallCam, 2017a)

2.2 Infrapunasädelaskurit

Infrapunasädelaskureilla tarkoitetaan vaakasuoraan asetettua infrapunasädettä, joka on suunnattu sisäänkäynnin yli. Kuva 1 havainnollistaa infrapunalaskurin käyttöä. Laskuri laskee yksilön automaattisesti säteen rikkoutuessa. Infrapunasädelaskuria pidetään yleisesti erittäin epätarkkana johtuen kyvyttömyydestä erotella samanaikaisesti tilaan saapuvat kävijät, sekä kyvyttömyydestä erottaa myymälään saapuminen tai sieltä poistuminen. (FootFallCam, 2017a)

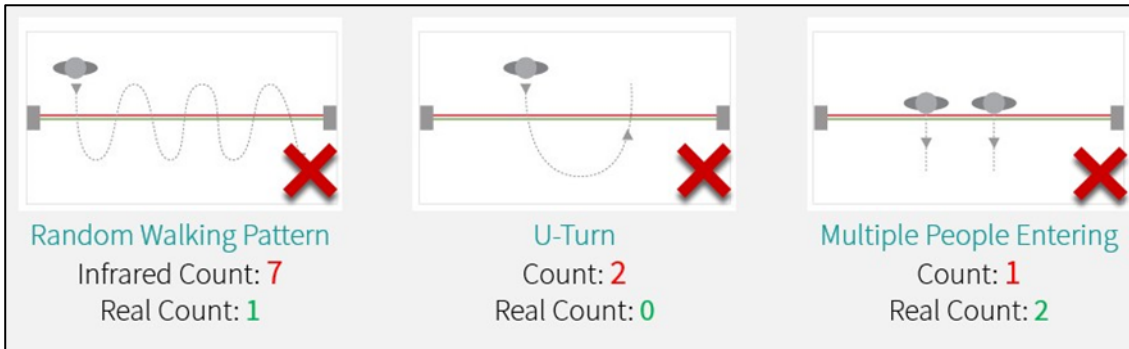
Odotettu tarkkuus infrapunasädelaskurille 60 % – 80 % (FootFallCam, 2017a).

Kuva 1 Infrapunasädelaskuri sijoitettuna oviaukolle (FootFallCam, 2017a).



Infrapunasädelaskurin keskeisiä virhelaskentoja aiheuttavat esimerkiksi oviaukolla edes takaisin liikkuminen, U-käännökset oviaukolla ja useamman henkilön yhtäaikainen sisäänkäynti, jolloin säde ei kykene erottelamaan henkilöitä. Kuva 2 havainnollistaa mahdollisia virhelaskentoja.


Kuva 2 Infrapunasädelaskurin laskennan virhetilanteita (FootFallCam, 2017a).



2.3 Lämpölaskurit

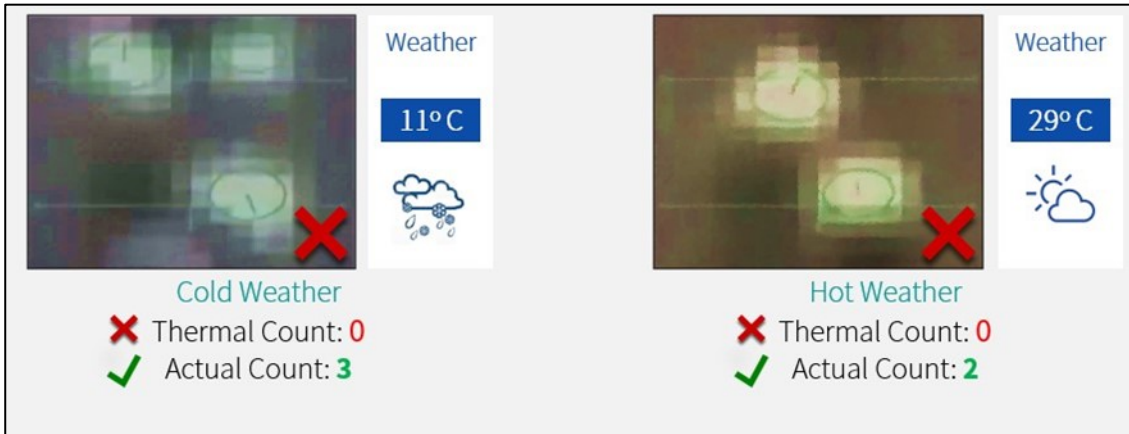
Lämpölaskureilla tarkoitetaan lämpökuvausjärjestelmiä, jotka käyttävät matriisiantureita lämmönlähteiden havaitsemiseksi sulautetun tekniikan avulla. Se on erittäin epäluotettava ympäristön esimerkiksi sään ja ilmankosteuden aiheuttamien epätarkkuuksien vuoksi. Kuvassa 3 on esitetty asennusta oviaukolle, sekä kuvaa miten kohteet tunnistetaan. Odotettu tarkkuus lämpölaskurille : 65 % – 85 %. (FootFallCam, 2017a)

Kuva 3 Lämpölaskurin toiminta oviaukolla (FootFallCam, 2017a).



Ympäristön olosuhteiden muutokset vaikuttavat lämpölaskurin toimintaan. Laitteen erottelukyky kärsii, kun olosuhteet poikkeavat optimista. Olosuhteiden vaikutusta on kuvattu kuvassa 4.

Kuva 4 Olosuhteiden vaikutus lämpölaskureiden toimintaan (FootFallCam, 2017a).



2.4 2D-henkilölaskuri

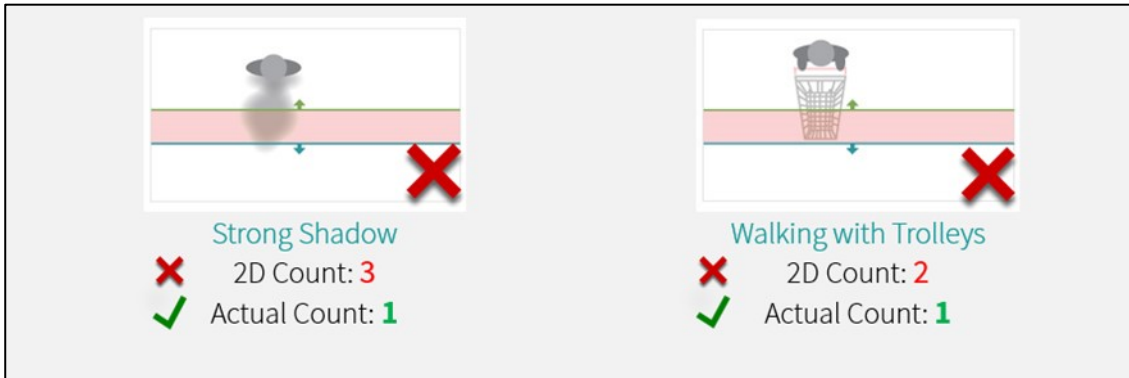
2D-henkilölaskureilla tarkoitetaan henkilölaskureita, jotka käyttävät kameran kuvaa tilaan tulevien tai sieltä poistuvien ihmisten määrän laskentaan suoraan kuvamateriaalista, havaitsemalla liikkeen taustalla. Laskuri asennetaan kulkuaukoille kuvassa 5 esitetyllä tavalla. Se on erittäin epätarkka, koska se ei pysty erottamaan esineitä ja ihmisiä toisistaan. Odotettu tarkkuus 2D-henkilölaskurille 80 % – 95 %. (FootFallCam, 2017a)

Kuva 5 2D-henkilölaskurit asennettuna oviaukolle (FootFallCam, 2017a).



Vahvat varjot, sekä esimerkiksi ostoskärryt voivat aiheuttaa virhelaskentoja 2D-henkilölaskuria käytettäessä. Kuvassa 6 kuvataan laskurin virhetilanteita.


Kuva 6 2D-henkilölaskureiden virhelaskentoja (FootFallCam, 2017a).



2.5 3D-henkilölaskurit

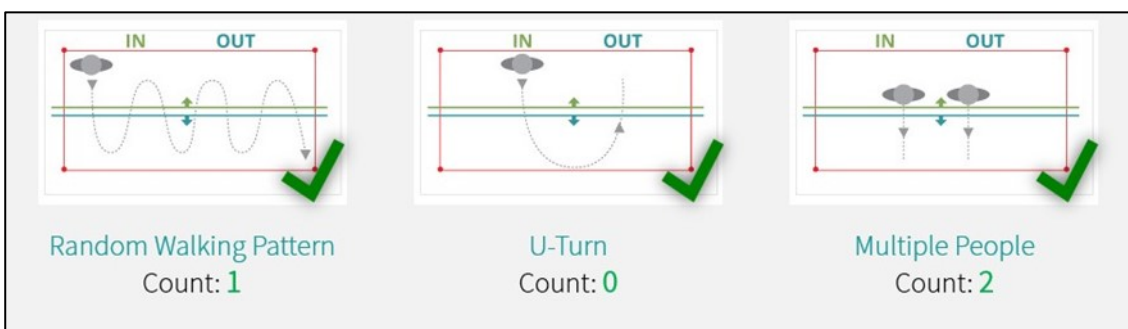
Neljännän sukupolven ihmislaskuri yhdistää kolmannen sukupolven ja Wi-Fi-laskentatekniikan, mikä antaa käyttäjille mahdollisuuden saada enemmän tietoa liiketoiminnasta kuin aikaisemmin. Lisäksi käyttämällä stereoskooppista näkemistä korkeuden havaitsemiseksi, neljännän sukupolven laskurit voivat tehokkaasti välttää kolmannen sukupolven laskureiden virheet laskennassa. Kuvassa 7 kuvataan laskurin toimitaa. Odotettu tarkkuus 3D-henkilölaskurille >95 %. (FootFallCam, 2017a)

Kuva 7 3D-henkilölaskuri oviaukolla laskee läpikulkeneiden henkilöiden määrän. Laskuri pystyy mittaamaan henkilömäärän myös Wi-Fi signaalin perusteella. (FootFallCam, 2017a)



3D-henkilölaskurit pystyvät seuraamaan henkilöä mitattavalla alueella ja estämään aikaisempien sukupolvien virhelaskennat oviaukolla. Tätä on kuvattu kuvassa 8.

Kuva 8 3D-henkilölaskurin toiminta (FootFallCam, 2017a).




2.5.1 Wi-Fi laskurit

Jokainen puhelin, jossa on Wifi päällä, lähettää Wifi signaalin 2-8 sekunnin välein. Jokainen Wifi signaali sisältää MAC osoitteen, joka on yksilöllinen jokaisessa puhelimessa. Tämän informaation avulla henkilö voidaan yksilöidä. Henkilön sijaintia voidaan arvioida signaalin voimakkuuden perusteella. Tämä toiminto sisältyy useimpiin WLAN-verkkojen hallinnan ohjelmistoihin. Kuva 9 esittää kerättyä dataa. (FootFallCam, 2017b)

Ciscon Meraki analytiikkapalvelut tarjoavat reaaliaikaista analytiikkaa WiFi laitteiden läsnäololle. Palvelu pystyy analysoimaan liikenteen vuorokaudenajan suhteen, uudet vs. palaavat vierailijat, sekä vierailijoiden viipymä aika. Hyviä käyttökohteita tälle olisi esimerkiksi kauppakeskuksissa capture raten mittaus, joka tässä yhteydessä tarkoittaa henkilömäärää, joka kulkee liikkeen ohi vs. liikkeeseen sisäänkäyneiden määrä. Palvelu tarjoaa myös asiakasuskollisuuden mittauksen, joka tarkoittaa uusien asiakkaiden määrää vs. palaavien asiakkaiden määrää. Nämä datat saadaan tulostettua myös graafisessa muodossa. (Cisco Systems, n.d.)

Kuva 9 Wi-Fi laskenta ja datan keräys FootfallCam (FootFallCam, 2017b).



2.6 Konenäköön perustuvat laskurit

Laitteina käytetään kameraa, sekä laskentayksikköä, jossa toimii hahmontunnistusalgoritmit. Hahmontunnistus tehdään suoraan videokuvasta kaappaamalla kuva kerrallaan, joka käsitellään hahmontunnistusalgoritmeilla, joita on saatavilla lukuisia erilaisia. Liikkuvista kohteista voidaan myös pirtää verkkorikenttiä kuvaamaan eri suuntiin kulkeneita henkilöitä.

Järjestelmä voidaan sijoittaa vapaammin mittaamaan haluttua aluetta verrattuna oviaukko mittauksiin. Järjestelmää voidaan käyttää myös rajoittamattomilla ulkoalueilla henkilömäärien laskemiseksi. Järjestelmän tarkkuus mitattaessa henkilömäärän kulkemista mittausalueen läpi esimerkiksi liiketilojen oviaukkomittauksissa on 98 % tasolla. (Windmill Software., 2019)

2.7 Johtopäätökset

Uusimmat lämpökamerat pystyvät laskemaan kävijämäärät riittävän tarkasti, mutta tietyn varauksin. Tätä teknologiaa kehitetään edelleen tarkkuuden ja luotettavuuden parantamiseksi. Saimme myös hyvän tarjouksen Terabee:lta lämpölaskureista, joilla voisi kattaa kulkuväylät kohtuullisen helposti (Terabee, n.d.). Tämä ei kuitenkaan olisi optimaalinen ratkaisu henkilömäärien laskentaan kaupan hedelmäosastolla tai kauppakeskuksissa, joissa on lukuisia kulkuväyliä, sekä avointa tilaa.

Testasimme myös erään suomalaisen IoT yrityksen kehittämää konenäköön perustuvaa järjestelmää. Järjestelmä mittasi kuvaan asetetun portin ohittaneiden henkilöiden määrän, eikä siten ominaisuuksiltaan eronnut oviaukoille sijoitetuista laskureista, muuten kuin mahdollistaen laitteiden vapaamman sijoittelun.

Tältä pohjalta keskityimme luomaan oman konenäköön perustuvan laitteen, jolla henkilömäärätieto voidaan kerätä avoimesta tilasta.

3 Konenäkö

Tietokonenäkö on tietojenkäsittelytieteen ala, joka keskittyy toistamaan ihmisen näköjärjestelmän monimutkaisia osia ja mahdollistaa tietokoneiden tunnistaa ja käsitellä kuvissa ja videoissa esiintyviä esineitä samalla tavalla kuin ihmiset. Viime aikoihin asti tietokonenäkö on toiminut vain rajoitetusti.

Keinotekoisien älykkyyden ja syvällisen oppimisen ja neuroverkkojen innovaatioiden ansiosta ala on onnistunut ottamaan suuria harppauksia viime vuosina ja pystynyt ylittämään ihmisen kyvyn joissakin esineiden havaitsemiseen ja merkitsemiseen liittyvissä tehtävissä.

Yksi tietokonenäön kasvun taustalla olevista tekijöistä on kasvanut tuottamamme datan määrä, jota käytetään sitten kouluttamaan ja parantamaan tietokonenäköä.

Yhdessä valtavan visuaalisen datamäärän kanssa (2019, yli 3 miljardia kuvaa jaetaan verkossa päivittäin), tietojen analysointiin tarvittava laskentateho on nykyään käytettävissä. Kun ala on kasvanut uusien laitteistojen ja algoritmien myötä, on kasvanut myös kohteen tunnistuksen tarkkuusaste. Tarkkuudet objektien identifiointiin ja luokitteluun ovat kehittyneet 50 prosentista 99 prosenttiin alle vuosikymmenen aikana, mikä tekee niistä ihmistä tarkempia reagoimaan nopeasti visuaalisiin syötteisiin. Kuvassa 10 on useita eri objekteja identifioitu ja luokiteltu. (Towards Data Science inc., 2019)

Kuva 10 YOLO Multi-Object Detection and Classification (Towards Data Science inc., 2019).



3.1 Konenäön historia

Aikaisimmat tietokonenäkökokeilut tehtiin 1950-luvulla, käyttäen joitain ensimmäisistä neuroverkoista kohteen reunojen havaitsemiseksi ja yksinkertaisten esineiden lajittelemiseksi luokkiin, kuten ympyrät ja neliöt. 1970-luvulla tietokoneyrityksen ensimmäinen kaupallinen käyttö tulkitsi kirjoitettua tai käsinkirjoitettua tekstiä optisen merkintunnistuksen avulla. Tätä edistystä käytettiin tulkitsemaan sokeille kirjoitettua tekstiä.

Kun Internet kypsyi 1990-luvulla ja suuret kuvajoukot olivat verkossa analysoitavissa, kasvojen tunnistusohjelmat kukoistivat. Nämä kasvavat tietojoukot auttoivat koneita tunnistamaan yksilöidyt ihmiset valokuvissa ja videoissa. (SAS Institute., n.d.)

3.2 Konenäön tulevaisuus

Konenäöllä ohjattujen robottijärjestelmien kasvavalla kysynnällä ja 3D-konenäköjärjestelmien lisääntyvällä käytöllä on merkittävä rooli teollisuuden konenäkömarkkinoiden kasvussa.

Teollisuuden konenäkömarkkinoiden kasvua hillitsevät loppukäyttäjien muuttuvat vaatimukset teollisuuden konenäkösovelluksille ja joustavien konenäköratkaisujen puute. Teollisuus 4.0:n ja tekoälyn lisääntyvä käyttöönotto luo todennäköisesti valtavia kasvumahdollisuuksia teollisuuden konenäkömarkkinoille.

Teollisuuden konenäkömarkkinoiden kokonaisarvoksi arvioitiin 11,0 miljardia Yhdysvaltain dollaria vuonna 2021, ja sen odotetaan nousevan 15,5 miljardiin dollariin vuoteen 2026 mennessä. (Research and Markets, 2021)

3.3 Konenäön sovelluksia

Tyypillisimpiä konenäön sovelluksien hyödyntämiskohteita ovat automaattinen kohteiden tunnistus, tapahtumien tunnistaminen, prosessien ohjaaminen sekä navigointi.

Seuraavassa joitakin esimerkkejä teollisuudessa käytetyistä konenäkösovelluksista.

3.3.1 Laadunvarmistus

Esimerkiksi puutuotetollisuudessa konenäköä on käytetty puun laadun arviointiin, jossa tuotantovaiheena on sahatavaran ja vanerin lajittelu perustuen puun oksien, reikien ja halkeamien perusteella. Vastaavaa menetelmää käytetään kananmunien laadunvarmistuksessa, jossa haljenneet kananmunat eristetään tuotantolinjalta.

Konenäköä voidaan hyödyntää tehokkaasti myös pakkausprosessissa. Pakkauksesta tunnistetaan pakatut komponentit ja puuttuvien komponenttien tapauksessa järjestelmä antaa hälytyksen. Näin voidaan estää puuttuvat komponentit toimituksista. (Jiglabs, n.d.) (Opetushallitus, 2004) (Viso.ai, n.d.)

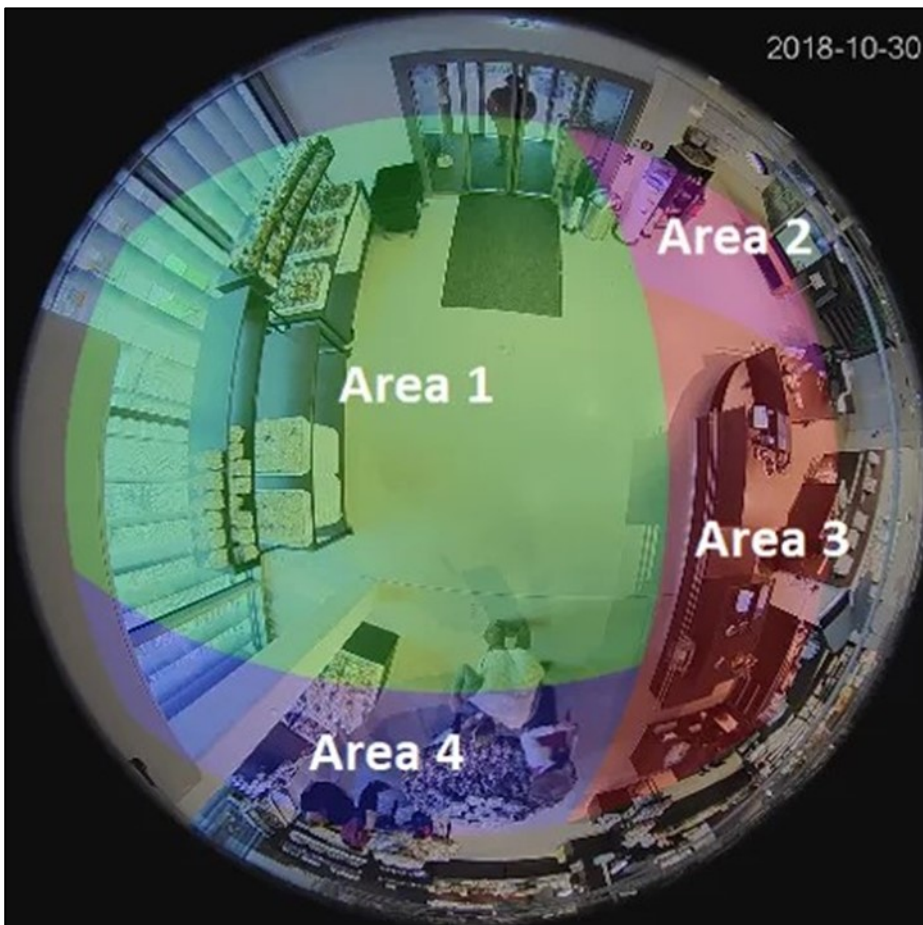
3.3.2 Toimitusketjun ohjaus

Konenäköä voidaan käyttää varaston hallinnassa, sekä hyllytätön ohjauksessa esimerkiksi tunnistamaan tyhjät hyllypaikat ja siten ohjata täydennystä. Samaa menetelmää voisi hyödyntää myös kaupan maitohyllyllä. (Viso.ai, n.d.)

3.3.3 Tuottavuuden kehitys tuotannossa

Konenäön avulla voidaan karkeasti mitata hukan ja lisäarvoa tuottavan työn määrää aikaperusteisesti. Tämä antaa ainakin perusymmärryksen tiettyjen hukan tyyppien suuruuteen. Kuva 11 esittää yhden mallin kuinka mitata tietyllä alueella käytettyä aikaa. (Viso.ai, n.d.)

Kuva 11 Yksi esimerkki miten mitata käytettyä aikaa tietyllä alueella (Viso.ai, n.d.).



4 Soveltuvat laitteet

Koska tarve on mitata myös avoimia tiloja, ei aikaisempien sukupolvien mittareita voida harkita käytettäväksi. Konenäkölaitteisto tarkoittaa kameraa, laskentayksikköä ja mahdollisesti verkkolaitteita, riippuen käyttötavasta.

Palvelu johon henkilömittari tarvitaan on pilotointiasteella, joten valmista datan siirtoa valittuun tietokantaan ei nyt tarvita. On myös mahdollista, että joissain tapauksissa voidaan käyttää asiakkaan verkkoa. Datan määrä on kuitenkin hyvin kevyttä, koska kuvaa ei tallenneta tai jaeta verkon yli. Käsittelemme kuitenkin hieman verkkolaitteita joilla laskuri voidaan asentaa erilliseksi yksiköksi.

4.1 Laskentayksiköt

Laskentayksikkönä voidaan käyttää erillistä työasemaa erityisesti, jos on halu ja tarve ajaa suurta kameramäärää samalla laskentayksiköllä.

Vaihtoehtona on sijoittaa laskentayksikkö kameroiden luokse erillisiksi yksiköiksi. Laskentayksikön laskentateho määrittää sen, kuinka monta kameraa voidaan käyttää laskentayksikköä kohden.

Konenäkösovelluksissa on laajalti käytössä myös älykameroita, joissa konenäön laskenta on sijoitettu itse kameraan. Tällöin kuvadatavirtaa ei tarvitse tuoda ollenkaan kamerayksikön ulkopuolelle.

Seuraavaksi käsitellään yleisiä helposti saatavilla olevia edge laskentayksiköitä, jotka soveltuvat henkilölaskuriksi.

4.1.1 Jetson Nano

Jetson Nano on tehokas laskentayksikkö sulautettuihin järjestelmiin ja tekoälysovelluksiin kuva 12.

Alkuun pääsee nopeasti JetPack SDK:n avulla, jossa on nopeutetut kirjastot syväoppimiseen, konenäköön sekä muuhun käyttöön. Veroton hintaluokka Jetson Nano laskentayksikölle Nvidian yhteistyökumppaneilta noin 60\$ (Arrow, n.d. a). Kokoonpano vaatii toimiakseen myös kotelon, jonka hinta on noin 30€ luokkaa radioduo verkkokaupassa, sekä noin 20€ maksavan 5VDC-4A virtalähteen (Radioduo, n.d.). Laitteen alustukseen ja käyttöönottoon vaaditaan myös näppäimistö, hiiri, sekä näyttö, joita voidaan tarpeen mukaan lainata muista kokoonpanoista. Kuvassa 13 on laskentayksikön spesifikaatio.

Kuva 12 NVIDIA Jetson Nano (Arrow, Jetson Nano, n.d. a).



Kuva 13 Jetson Nano spesifikaatio (Developers, n.d. a).

TECHNICAL SPECIFICATIONS	
GPU	NVIDIA Maxwell architecture with 128 NVIDIA CUDA® cores
CPU	Quad-core ARM Cortex-A57 MPCore processor
Memory	4 GB 64-bit LPDDR4, 1600MHz 25.6 GB/s
Storage	16 GB eMMC 5.1
Video Encode	250MP/sec 1x 4K @ 30 [HEVC] 2x 1080p @ 60 [HEVC] 4x 1080p @ 30 [HEVC] 4x 720p @ 60 [HEVC] 9x 720p @ 30 [HEVC]
Video Decode	500MP/sec 1x 4K @ 60 [HEVC] 2x 4K @ 30 [HEVC] 4x 1080p @ 60 [HEVC] 8x 1080p @ 30 [HEVC] 9x 720p @ 60 [HEVC]
Camera	12 lanes (3x4 or 4x2) MIPI CSI-2 D-PHY 1.1 (1.5 Gb/s per pair)
Connectivity	Gigabit Ethernet, M.2 Key E
Display	HDMI 2.0 and eDP 1.4
USB	4x USB 3.0, USB 2.0 Micro-B
Others	GPIO, I ² C, I ² S, SPI, UART
Mechanical	69.6 mm x 45 mm 260-pin edge connector

4.1.2 Jetson Xavier

Nvidian Jetson malliston tehoikkaammasta päästä löytyy Xavier AGX malli, joka suoriutuu raskaammastakin laskennasta (kuva 14). Suorituskyky on 20-kertainen aiempaan NVIDIA Jetson TX2 -suoritinsukupolven verrattuna (NVIDIA, n.d.). Veroton hintaluokka Xavier AGX mallille Nvidian yhteistyökumppaneilta 700\$ (Arrow, n.d. b). Xavier AGX laskentayksikön spesifikaatio on esitetty kuvassa 15.

Tällainen laskentayksikkö olisi projektin käytettävissä, mutta kevyempiin käyttökohteisiin, jossa käytetään esim. yhtä kameraa, olisi tämä turhan ylimitoitettu. Raskaampaan, usean kameran laskentaan Xavier AGX on kuitenkin hyvä valinta myöhempää käyttöä varten.

Kuva 14 Jetson Xavier AGX kuvattuna lot-Analyticsin toimistolla.



Kuva 15 Jetson Xavier AGX tekninen spesifikaatio (NVIDIA, n.d.).

The Tech Specs	
AI Performance	32 TOPs
GPU	512-core Volta GPU with 64 Tensor Cores 11 TFLOPS (FP16) 22 TOPS (INT8)
CPU	8-core Carmel ARM v8.2 64-bit CPU, 8MB L2 + 4MB L3
Memory	32GB 256-Bit LPDDR4x 136.5GB/s
Storage	32GB eMMC 5.1
DL Accelerator	[2x] NVDLA Engines* 5 TFLOPS (FP16), 10 TOPS (INT8)
Vision Accelerator	7-way VLIW Vision Processor*
Video Encode	2x1000MP/sec 4x 4K @ 60 (HEVC) 8x 4K @ 30 (HEVC) 16x 1080p @ 60 (HEVC) 32x 1080p @ 30 (HEVC)
Video Decode	2x1500MP/sec 2x 8K @ 30 (HEVC) 6x 4K @ 60 (HEVC) 12x 4K @ 30 (HEVC) 26x 1080p @ 60 (HEVC) 52x 1080p @ 30 (HEVC) 30x 1080p @ 30 (H.264)
Size	105 mm x 105 mm

Suorituskykyvertailu eri Jetson laitteiden välillä tuo hyvin esiin Xavier AGX mallin hurjan laskentatehon. Esimerkkinä edge laitteissa käytetyllä Tiny YOLO V3 hahmontunnistuksella FPS on 23-kertainen Nanon verrattuna. Kuvassa 16 on Jetson tuoteperheen suorituskykyvertailu.

Kuva 16 Jetson tuotteen suorituskykyvertailu (Developers, n.d. b).

Model	Jetson Nano		Jetson TX2 series		Jetson Xavier NX		Jetson AGX Xavier	
	FPS (limited latency)	FPS (max throughput)	FPS (limited latency)	FPS (max throughput)	FPS (limited latency)	FPS (max throughput)	FPS (limited latency)	FPS (max throughput)
Inception V4 (299x299)	11*	13	24*	32	320	405	528	704
VGG-19 (224x224)	10*	12	23*	29	67*	313	276	432
Super Resolution (481x321)	15*	15	33*	33	164	166	281	302
Unet (256x256)	17*	17	39*	39	166	166	240	251
OpenPose (256x456)	15*	15	34*	35	238	271	439	484
Tiny YOLO V3 (416x416)	48*	49	107	112	607	618	1100	1127
ResNet-50 (224x224)	37*	47	84	112	824	1100	1946	2109
SSD Mobilenet-V1 (300x300)	43*	48	92	109	909	1058	1602	1919
SSD Resnet34 (1200x1200)	1	1	3	2	29	29	55	55
BERT_BASE (seq length = 128)	BERT requires Volta or newer		BERT requires Volta or newer		115	115	277	286
BERT_LARGE (seq length = 128)	BERT requires Volta or newer		BERT requires Volta or newer		32	35	86	90

* Latency more than 15ms.


4.1.3 Raspberry Pi4 model B

”Raspberry Pi, tuttavallisemmin RasPi, on yhden piirilevyn tietokone, jonka on kehittänyt brittiläinen Raspberry Pi Foundation. Tietokoneet valmistetaan Walesissa Sonyn Pencoedin tehtaalla”. (Wikipedia, 2022)

Raspberry Pi 4 versio julkaistiin vuonna 2019 ja on saatavilla 2Gb, 4Gb, 8Gb muistilla tarjoten n. kolminkertaisen suorituskyvyn verrattuna edelliseen versioon. Suorittimena toimii 1,5GHz neliytiminen 64-bittinen ARM-prosessori. Raspberry Pi on edullinen tietokone ja soveltuu etenkin konenäkösovellusten protyyppien testaukseen, sekä pilotointiin edge laitteena. Raspberry Pi 4 esitetty kuvassa 17. (Wikipedia, 2022)

Raspberry Pi:hin on saatavilla 64 bittinen käyttöjärjestelmä, jonka avulla saadaan lisää suorituskykyä.

Kuva 17 Raspberry Pi 4 (Raspberry Pi Foundation, n.d.).



On raportoitu ettei Raspberry Pi ole riittävän suorituskykyinen konenäkösovelluksiin, mutta uuden Raspberry Pi 4 tuoman merkittävästi paremman suorituskyvyn avulla ainakin kevyemmät algoritmit toimivat jopa sujuvasti. Muistina 4Gb on riittävyyden rajoilla konenäkösovelluksissa ilman muistinhallinnan optimointia. Konenäkösovelluksiin kannattaa harkita vain hieman kalliimpaa 8Gb versiota.

Raspberry Pi 4 mukana tuli päivitys grafiikkasuorittimeen ja parannettu kaistanleveys muistille ja ulkoiselle laitteistolle.

Raspberry Pi 4 spesifikaatio

- SoC: Broadcom BCM2711B0 quad-core A72 (ARMv8-A) 64-bit @ 1.5GHz
- GPU: Broadcom VideoCore VI
- Networking: 2.4 GHz and 5 GHz 802.11b/g/n/ac wireless LAN
- RAM: 1GB, 2GB, or 4GB LPDDR4 SDRAM
- Bluetooth: Bluetooth 5.0, Bluetooth Low Energy (BLE)


- GPIO: 40-pin GPIO header, populated
- Storage: microSD
- Ports: 2 × micro-HDMI 2.0, 3.5 mm analogue audio-video jack, 2 × USB 2.0, 2 × USB 3.0, Gigabit Ethernet, Camera Serial Interface (CSI), Display Serial Inter-face (DSI)
- Dimensions: 88 mm × 58 mm × 19.5 mm, 46 g

Raspberry Pi4 model B 4Gt muistilla maksaa Suomalaisessa verkkokaupassa noin 85€. Tämän lisäksi järjestelmä vaatii virtalähteen ja muistikortin. Lisäksi tarvitaan näppäimistö, hiiri, sekä näyttö laitteen alustukseen ja käyttöönottoon. Virallinen Raspberry pi 4 virtalähde maksaa noin 20€. Jäähdytetty kotelo noin 20€ ja muistikortti noin 10€. (Verkkokauppa.com, n.d.)

Kaikki laitteen tieto tallennetaan muistikortille, joten toisen laitteen alustaminen vaatii vain kopion muistikortista.

Raspberry Pi:ssä on kaksi micro HDMI liitäntää, joilla voidaan haluttaessa ajaa kahta 4K näyttöä 30FPS tai yhtä näyttöä 4Kp60 (kuva 18).


Kuva 18 Micro HDMI liitännät (Raspberry Pi Trading, 2019).



4.1.4 Raspberry Pi:n suorituskyvyn kehitys

Alun perin supertietokoneille kehitetty synteettinen vertailuarvo Linpack näyttää Raspberry Pi4 merkittävän kehityksen verrattuna aikaisempiin Raspberry Pi versioihin (kuva 19).

Kuva 19 Raspberry versioden kehitys (Raspberry Pi Trading, 2019).



4.1.5 Suorituskykyvertailu Raspberry Pi 4 vs. Jetson Nano

Raspberry Pi 4:n suorituskyvyn parantuminen Raspberry Pi 3 versioon verrattuna on merkittävä, mutta ei silti yllä Jetson Nanon tasolle hahmontunnistusalgoritmejä käytettäessä, jossa on erillinen NVIDIA Maxwell w/ 128 CUDA cores @ 921 Mhz grafiikkasuoritin. Suorituskykyvertailu on esitetty kuvassa 20.

Q-engineering suorittamassa vertailussa olevat laitteet ovat ylikellotettuja antaen hieman paremman tuloksen kuin tehdasasetuksin. Huomioitavaa on myös Raspberry Pi:n 64 bittinen käyttöjärjestelmä.

Tietokonenäköalalla mAP(mean Average Precision) on suosittu arviointimittari mittaamaan käytetyn mallin ennusteiden tarkkuutta. Tätä käytetään objektien paikallistamiseen ja luokitteluun. Lokalisointi määrittää ilmentymän sijainnin esim. rajauslaatikon koordinaatit ja luokitus kertoo mikä se on esim. koira tai kissa. Tässä tapauksessa tarkkuus tarkoittaa ennusteiden

tarkkuutta, eli prosenttiosuutta jossa mallin tekemät ennusteet olivat oikein.

(Towardsdatascience, 2020a)

Vertailussa on myös mitattu kuvan päivitysnopeus FPS (Frames Per Second). Tässä yhteydessä se tarkoittaa, kuinka monta kuvaa pystytään käsittelemään ja tuottamaan haluttu tuotos sekunnissa.

(Towardsdatascience, 2020b)

Kuva 20 Jetson Nano vs. Raspberry Pi 4 suorituskyky eri hahmontunnistusalgoritmeilla (Q-engineering, 2021a).

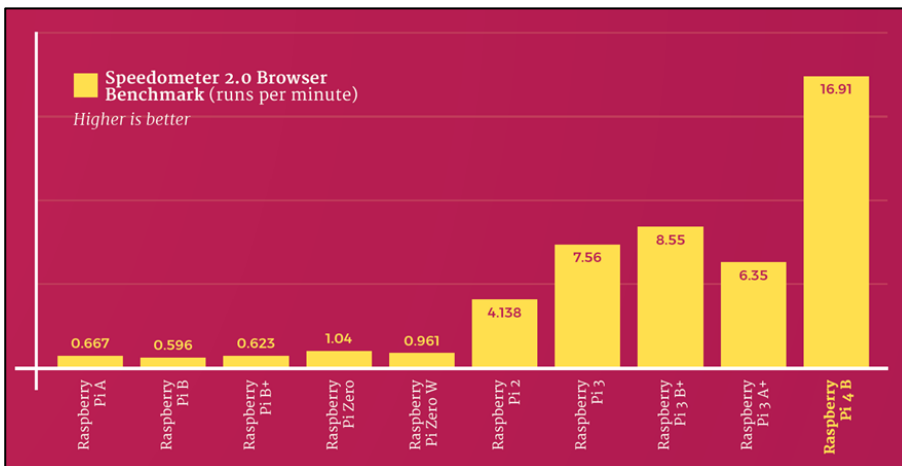
Model	size	objects	mAP	Jetson Nano 2015 MHz	RPi 4 64-OS 1950 MHz
NanoDet	320x320	80	20.6	28.2 FPS	13.0 FPS
YoloV2	416x416	20	19.2	10.1 FPS	3.0 FPS
YoloV3	352x352 tiny	20	16.6	17.7 FPS	4.4 FPS
YoloV4	416x416 tiny	80	21.7	11.2 FPS	3.4 FPS
YoloV4	608x608 full	80	45.3	0.7 FPS	0.2 FPS
YoloV5	640x640 small	80	22.5	4.0 FPS	1.6 FPS

Ero ei kuitenkaan ole merkittävä henkilölaskuria rakennettaessa, sillä kuvattavalla alueella henkilömäärät ei muutu kovinkaan nopeasti, jolloin myös Raspberry Pi4:n suorituskyky on riittävä.

4.1.6 Speedometer 2.0 selaimen nopeustesti

Speedometer mittaa Chromium verkkoselaimen reagoivuutta suorittamalla verkkosovelluksen tehtäväluettelon ja mittaamalla kuinka monta kertaa sovellus voidaan suorittaa minuutissa. Tässä suorituskyky riippuu paitsi suorittimen suorituskyvystä, myös muistin nopeudesta ja kapasiteetista. Nopeustestin tulokset on esitetty kuvassa 21. (Raspberry Pi Trading, 2019)

Kuva 21 Speedometer 2.0 nopeustesti (Raspberry Pi Trading, 2019).



4.1.7 Muistin kaistanleveys

Usein suorittimen nopeus on suorituskyykyä rajoittava tekijä. Osin työvaiheiden suorituskyyky nojaa muistin kaistanleveyteen, jolla tietoa voidaan lukea ja kirjoittaa RAM muistiin. Tässä vertailussa RAM nopeutta / SMP työkalua käytetään mittaamaan 1Mt kokoisten lohkojen luku- ja kirjoituskaistanleveyttä megabittinä sekunnissa (MBps). Kuvassa 22 on testattu muistin kaistanleveyttä eri Raspberry Pi -versioilla. (Raspberry Pi Trading, 2019)

Kuva 22 Muistin kaistanleveys (Raspberry Pi Trading, 2019).

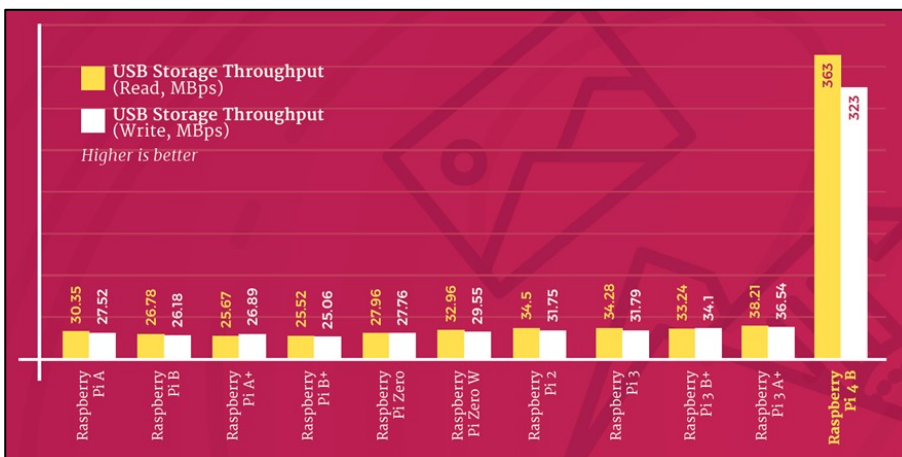


4.1.8 USB muistin läpimeno

Raspberry Pi 4:ssä on USB 3.0-portit tarjoavat merkittävän kaistanleveyden parannuksen, joilla on suuri vaikutus ulkoisten kovalevyjen suorituskykyyn. Tässä SSD-asema kytketään USB-sovittimen kautta ja keskimääräinen luku ja -kirjoitusnopeus mitataan megatavuina sekunnissa (MBps). Luku- ja kirjoitusnopeuden parannus on esitetty kuvassa 23. (Raspberry Pi Trading, 2019)

Pitkäaikaisempaa käyttöä varten SSD asema olisi järkevä ottaa käyttöön SD muistia suuremman nopeuden, sekä kestävyuden vuoksi. Tälle projektille ei sellaista tarvetta kuitenkaan tullut.

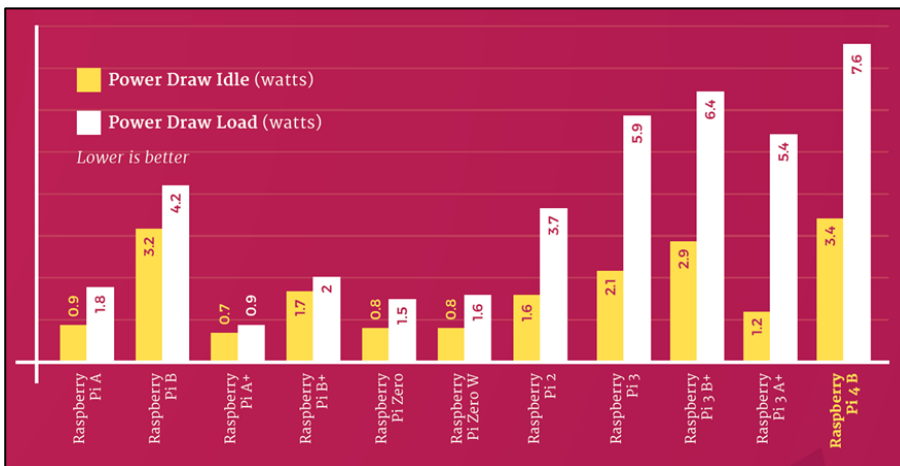
Kuva 23 USB luku- ja kirjoitusnopeus (Raspberry Pi Trading, 2019).



4.1.9 Virrankulutus

Suurempi suorituskyky tarkoittaa tyypillisesti enemmän virtaa ja tässä jokaiselle Raspberry Pi -mallille jätetään suorittimen intensiivinen vertailuarvo, kun HDMI-näyttö, USB-näppäimistö ja hiiri on kytketty. Huipputeho watteina mitataan seinältä, sekä vertailun vuoksi tyhjäkäynnillä Raspberry Pi:n Raspbian työpöydältä. Kuvassa 24 on vertailtu eri Raspberry Pi -versioiden virrankulutuksia. (Raspberry Pi Trading, 2019)

Kuva 24 Raspberry Pi eri versioiden virrankulutus (Raspberry Pi Trading, 2019).



Uusimman Raspberry Pi4:n merkittävimmät muutokset ovat nopeampi prosessori, enemmän ja nopeampaa muistia, sekä kaksinkertainen nopeus microSD muistille. Kuvassa 25 on Raspberry Pi sukupolvet vertailussa.

Kuva 25 Raspberry Pi sukupolvet (Wikipedia, 2022).

	Raspberry Pi 1 (Model B+)	Raspberry Pi 2 (Model B)	Raspberry Pi Zero	Raspberry Pi 3 (Model B v1.2)	Raspberry Pi 4 Model B
Julkaisupäivä:	14.7.2014	2.2.2015	26.11.2015	29.2.2016	24.6.2019
Myyntihinta:	25 USD	35 USD	5 USD	35 USD	35 USD
Prosessori:	700 MHz, yksiytiminen, ARM11, 32-bittinen, ARMv6	900 MHz, moniydinprosessori, ARM Cortex-A7, 32-bittinen, ARMv7-A	1 GHz, yksiytiminen, ARM11, 32-bittinen, ARMv6	1.2 GHz, moniydinprosessori, ARM Cortex-A53, 64-bittinen, ARMv8-A	1.5 GHz, moniydinprosessori, ARM Cortex-A72, 64-bittinen, ARMv8-A
Näytönohjain:	Broadcom VideoCore IV, OpenGL ES 2.0, 1080p, h.264, 250MHz			Broadcom VideoCore IV, OpenGL ES 2.0, 1080p, h.264, 400MHz	Broadcom VideoCore VI, OpenGL ES 3.0, 1080p, h.265, 500MHz
Piirisarja:	Broadcom BCM2835 (CPU, GPU, DSP, SDRAM)	Broadcom BCM2836 (CPU, GPU, DSP, SDRAM)	Broadcom BCM2835 (CPU, GPU, DSP, SDRAM)	Broadcom BCM2837 (CPU, GPU, DSP, SDRAM)	Broadcom BCM2711 (CPU, GPU, DSP, SDRAM)
Muisti:	512 Mt (jaeettu näytönohjaimen kanssa)	1 Gt (jaeettu näytönohjaimen kanssa)	512 Mt (jaeettu näytönohjaimen kanssa)	1 Gt (jaeettu näytönohjaimen kanssa)	1/2/4/8 Gt LPDDR4-2400 (jaeettu näytönohjaimen kanssa)
USB 2.0 portit:	4 kpl		2 kpl (microUSB)	4 kpl	
Videoulostulot:	HDMI (rev 1.4), komposiitti RCA (PAL & NTSC), Model A+/B+ jakkiliitin korvaa RCA:n		miniHDMI, GPIO (komposiitti)	HDMI (rev 1.4), komposiitti RCA (PAL & NTSC), Model A+/B+ jakkiliitin korvaa RCA:n	
Ääni:	HDMI, 3,5 mm jakki		miniHDMI, GPIO	HDMI, 3,5 mm jakki	
Massamuisti:	SD / MMC / SDIO-muistikortti, Model A+/B+ vain Secure Digital				
Verkkosovitin:	10/100 Ethernet (RJ45) (USB-Ethernet-silta)	10/100 Ethernet (RJ45) (USB-Ethernet-silta)	Ei ole	10/100 Ethernet (RJ45) (USB-Ethernet-silta)	10/100/1000 Ethernet (RJ45)
Langattomat yhteydet:	Ei ole			802.11n ja Bluetooth 4.1	
Muut liittimet:	40-pinninen GPIO-liitin				
Tehonkulutus:	1,55 W (310 mA)	2,1 W (420 mA)	0,8 W (~160 mA)	2,9 W (580 mA)	3,4 W (580 mA)
Virtalähde:	5 V MicroUSB				
Koko:	85,60 × 53,98 × 17 mm		65 mm × 30 mm × 5 mm	85,60 × 53,98 × 17 mm	88 × 58 × 19.5 mm
Paino:	45 g		9 g	45 g	
Käyttöjärjestelmät:	Arch Linux, Debian (Raspbian), Fedora (Pidora), RISC OS, Slackware, Windows 10 IoT				

4.2 Kamerat

Kameroiden testaaminen aloitettiin olemassa olevalla web-kameralla, jonka avulla päästiin testaamaan hahmontunnistusalgoritmejä. Tämä ei voinut olla lopullinen ratkaisu etenkin ulkonäön ja kiinnityksen vuoksi, joten hankittiin lisäksi Dahuan IP-kameroita. Vaihtoehtoiseksi ratkaisuksi testattiin myös Raspberryn kameraa erittäin pienen kokonsa vuoksi. Tällainen pieni kamera ei herätä huomiota samalla tavalla kuin isompi IP-kamera.

4.2.1 Logitech C920 webkamera

Projektissa testattiin ensimmäisenä olemassa olevaa Logitechin C920 webkameraa (kuva 26), joka on varustettu USB liittimellä. Tällä kameralla päästiin testaamaan ensimmäisiä hahmontunnistusalgoritmejä.

Kuvan laatu on erittäin hyvä lähietäisyydellä johon kamera on suunniteltu. Kamera ei kuitenkaan ole käyttökelpoinen lopullista ratkaisua varten.

Kuva 26 Logitech C920 webkamera (Logitech, n.d.).



Logitech C920 tarjoaa 1080p30 kuvan tarkkuuden H.264-kuvan pakkauksella. Kamerassa on automaattitarkennus ja liitännänä USB-A. (Logitech, n.d.)

Kameran kuvan lukeminen käyttäen OpenCV kirjastoa onnistuu komennolla `cv2.VideoCapture(0)`. Tämä avaa oletuksena Raspberryn kameran tai jos Raspberryn kameraa ei ole asennettu, aukeaa web-kameran kuva.

4.2.2 Raspberry Pi kamerat

Raspberry Pi kameramoduli v2 korvasi alkuperäisen kameramoduulin huhtikuussa 2016. Kameramoduulissa on Sony IMX219 8.0 Mpix sensori, joka tukee maksimissaan 3280 x 2464 tarkkuutta yksittäiskuvana, sekä 1080p30, 720p60, VGA90 videokuvaa. Vertailuna alkuperäisessä kamerassa oli 5Mpix Omnivision OV5647 sensori. Kamera voidaan liittää suoraan Raspberry Pi:n CSI porttiin. (Raspberrypi, n.d. a)

Projektissa testattiin myös tätä v2.1 kameramoduulia. Kokonsa puolesta kamera saadaan asennettua Raspberry Pi:n kanssa hyvin huomaamattomasti. Kamera vaatii pienen kotelon, joka saadaan helposti vaikka 3D-tulostettua. Kuvassa 27 on esitetty Raspberry Pi v2.1 kameramoduuli.

Kuva 27 Raspberry Pi 8.0 Mpi kameramoduuli v2.1.



Raspberrylle löytyy myös uudempi 12.3 Mpi kamera (kuva28), jossa on Sonyn IMX477 sensori (Raspberrypi, n.d. b). Tämän kameran hinta sijoittuu hyvän IP-kameran ja v2.1 kameramoduulin väliin.

Kuva 28 Raspberry Pi uusin HQ kamera 12,3 Mpix (Raspberrypi, n.d. b).



4.2.3 Dahua IP-kamera

Projektissa käytettiin myös Dahua IPC-HFW2231S -kameraa (kuva29), jonka kuvaan pääsee käsiksi RSTP osoitteella. Kamerassa on PoE -tuki jolloin kameran voi kytkeä ilman virtalähdettä PoE kytkimeen. Tällaiset kamerat tulevat kyseeseen ulkotiloissa tai tapauksissa, joissa käytetään useampaa kameraa laskentayksikköä kohden.

Kuva 29 Dahua IP-kamera mallia IPC-HFW2231S-S-S2 kuvattuna lot-Analyticsin tiloissa.



Dahua Starlight tekniikan avulla kamera kykenee tuottamaan värillistä kuvaa minimissään 0.002 Lux @ F1.6 valaistuksessa. Tästä alhaisemmassa valaistuksessa kamera käynnistää automaattisesti IR LEDin joka valaisee kuvattavan alueen maksimissaan 30m saakka. (Suomenturvatuote, n.d. a)

Kameran käyttölämpötila alue on -40 ... +60C. Kamerassa on myös IP67 luokitus. Näillä ominaisuuksilla kamera soveltuu myös ympärivuotiseen ulkokäyttöön. Kameran tekniset ominaisuudet on esitetty kuvassa 30.

Kuva 30 dahua-ipc-hfw2231s-s-s2 tekniset ominaisuudet (Suomenturvatuote, n.d. a).

Valmistaja	Dahua
Tuotekoodi	IPC-HFW2231S-S-S2
Kuvakenno	1/2.8" 2Megapixel progressive CMOS
Resoluutio	1920x1080p
Min. valontarve	0.002 Lux @F1.6 0 Lux @F1.6 (IR on)
IR valaistus (pimeäkuvaus)	Max 30m
IR ledien määrä	1kpl
Linssi	Kiinteä
Polttoväli	3.6mm
Kuvalaajuus	Vaaka 87° Pysty 46°
IVS	Tripwire (ansalanka), Intrusion (hälytysalue)
Videopakkaus	H.265; H.264; H.264B; MJPEG
Kuvataajuus (Frame Rate)	1920x1080p @25/30fps
Bit Rate	H.265: 12 Kbps–6144 Kbps
Kuvankorjausominaisuudet	BLC/HLC
WDR	120dB
Kohinan vaimennus	3D DNR
ROI (Kiinnostavat alueet)	Kyllä (4 aluetta)
Digitaalinen zoomi	16x
Käyttöjännite	DC12V
PoE tuki	Kyllä
Tehon kulutus	<4.9W
Käyttölämpötila	-40°C ~ +60°C
Kotelointiluokka	IP67
Ilkivaltasuojaus	EI
Mitat	166.2 mm × Ø70 mm

Projektissa yhtenä haasteena oli myös saada IP kamera kytkettyä Raspberry Pi 4:ään. Kamerakohtaiset osoitteet löytyvät valmistajalta tai kamera-asetusten koontisivustoilta.

Kuvan lukeminen käyttäen OpenCV kirjastoa onnistuu seuraavalla komennolla.

cv2.VideoCapture

('rtsp://USERNAME:PASSWORD@IP_ADDRESS:554//cam/realmonitor?channel=1&subtype=0')

Kameran asetukset ja salasana kannattaa alustaa ensin kameran hallintasovelluksessa.

4.3 Verkkolaitteet

Projektissa ei tarvittu datan siirtoa, mutta tulevia tarpeita ajatellen tarvittavat laitteet on hyvä kartoittaa.

Ethernet yhteyksiä käyttäen verkkolaitteet käsittävät Raspberry Pi:n, kytkimen, johon Raspberry Pi sekä IP-kamerat kytketään, ja reititin jolla data siirretään verkon yli.

Datan keräämiseen ei tarvittu reititintä, mutta tulevia tarpeita ajatellen haettiin kokoonpano, jolla dataa voidaan siirtää omaa verkkoa käyttäen.

4.3.1 Dahua PoE kytkin

Useampaa IP-kameraa käytettäessä kamerat voidaan kytkeä erilliseen kytkimeen. Kun käytetään PoE-tyyppistä kytkintä, jota kamera tukee, voidaan kameran tarvitsema virta ottaa kytkimestä. Tässä Dahuan PFS3010-8P-96 kytkimessä (kuva 31) on kahdeksan PoE tuettua 10/100 Base-T ethernet porttia, yksi 10/100/1000 Base-T sekä yksi Gigabit 1000 Base-X ethernet portti. Kytkintä voi käyttää sisä- ja ulkotiloissa. Kytkimen tekniset ominaisuudet on esitetty kuvassa 32.

Kuva 31 Dahua PFS3010-8P-96 kytkin kuvattuna IoT-Analyticsin tiloissa.



Kuva 32 Dahua-pfs3110-8p-96 tekniset ominaisuudet (Suomenturvaluote, n.d. b).

Valmistaja	Dahua
Tuotekoodi	PFS3010-8P-96
Ethernet- portit	1*1000 Base-X 1*10/100/1000 Base-T 8*10/100 Base-T (PoE power supply)
PoE- virrankulutus (maksimissaan)	Portti 1-8 ≤30W, yhteensä ≤96W
PoE- protokollat	IEEE802.3af (PoE), IEEE802.3at (PoE+),
Kytkeäkapasiteetti	7.6G
Edelleenlähetyksenopeus	4.17Mpps
Virtalähde	DC 48V ~ 57V
Käyttölämpötila	-30°C ~ 65°C
Mitat	150mm x 100mm x 42mm

4.3.2 Teltonika RUT240 reititin

Reitittimenä testattiin Teltonikan RUT240 reititintä (kuva 33). Raspberryssä on LAN, sekä WiFi yhteydet joilla saadaan yhteys reitittimeen. Vaihtoehtoisesti voidaan käyttää kytkintä välissä, jos on tarvetta kytkeä IP-kameroita verkkoon. Reitittimen tekniset ominaisuudet on esitetty kuvassa 34.

Kuva 33 Teltonika RUT240 reititin kuvattuna IoT-Analyticsin tiloissa.



Kuva 34 Teltonika-rut240-4g-lte tekniset ominaisuudet (Suomenturvaluote, n.d. c).

- Täysikokoinen SIM-korttipaikka
- LTE: jopa 150 Mbps latausnopeus ja 50 Mbps paluunopeus
- HSPA+: jopa 42 Mbps latausnopeus ja 5,76 Mbps paluunopeus
- LTE-taajuudet: 800/850/900/1800/2100/2600 MHz
- 3G-taajuudet: 850/900/2100 MHz
- 3G/4G-antennit vaihdettavissa, SMA-liitin
- WLAN: 802.11bgn, 150Mbps
- WLAN-antenni vaihdettavissa, RP-SMA-liitin
- jopa 50 samanaikaista WLAN yhteyttä
- 2 x Ethernet 10/100 Mbps (WAN + LAN)
- 3/4G-vara-WAN-toiminto
- Open VPN ja Dyn DNS-valmiudet
- ping- ja tekstiviesti-uudelleenkäynnistys
- tekstiviestihallinta
- digitaalinen I/O (releliitäntä, jonka käyttö edellyttää erillisen terminaalikaapelin 50960 käyttöä myös virtakaapelina)
- alumiinikotelo
- käyttöjännite: 9 - 30 VDC (sisältää virtalähteen)
- käyttölämpötila: -40°C...+75°C

5 Toteutus

Laskentayksikkönä käytettiin Raspberry Pi4 4Gt versiota, jossa kaikki asennukset suoritetaan microSD muistikortille. Datat lukemisen ja kirjoittamisen viiveiden minimoimiseksi muistin tulee olla nopeaa. Latausten nopeuttamiseksi olisi mahdollista käyttää USB liitäntäistä kiintolevyä, mutta sille ei ollut nyt tarvetta. Muistiksi valittiin SanDisk ultra microSDHC (kuva 35), jonka nopeus on max. 98 MB/s.

Kuva 35 Projektissa käytetty microSD muistikortti kuvattuna IoT-Analyticsin tiloissa.



5.1 Käyttöjärjestelmän asennus

Käyttöjärjestelmäksi valittiin vielä kehitysvaiheessa oleva 64-bittinen Raspberry Pi OS - käyttöjärjestelmä, joka asennettiin muistikortille Raspberry Pi Imager ohjelmaa käyttäen. Käyttöjärjestelmä toimii vakaasti, vaikka on vielä beta-versio.

Raspberry Imager tukisi myös eri Ubuntu versioita, mutta nämä ovat hitaampia syväoppimissovelluksissa. Alla kuvassa 36 on testituloksia Tensor Flow malleille eri käyttöjärjestelmillä testattuna. (Q-engineering, n.d. a)

Kuva 36 Käyttäjärjestelmien vaikutus kuvan päivitysnopeuteen eri käyttäjärjestelmillä käyttäen Tensor Flow malleja (Q-engineering, n.d. a).

Model	Raspberry Pi 4 64 bit OS 1950 MHz	Raspberry Pi 4 64 bit OS 1500 MHz	Raspberry Pi 4 64 bit Ubuntu 1850 MHz	Raspberry Pi 4 64 bit Ubuntu 1500 MHz	Raspberry Pi 4 32 bit OS 1950 MHz	Raspberry Pi 4 32 bit OS 1500 MHz
MobileNet-V1 SSD (300x300)	26.8 FPS	21.5 FPS	24.0 FPS	17.2 FPS	17.0 FPS	13.8 FPS
MobileNet-V1 (224x224)	38.5 FPS	32.2 FPS	22.9 FPS	22.5 FPS	33.0 FPS	22.2 FPS
MobileNet-V2 (224x224)	45.5 FPS	37 FPS	19,7 FPS	19,5 FPS	36.2 FPS	28.0 FPS
Inception-V2 (224x224)	11.6 FPS	9.5 FPS	10.0 FPS	8.7 FPS	8.9 FPS	6.9 FPS
Inception-V4 (299x299)	2.1 FPS	1.7 FPS	2.0 FPS	1.8 FPS	1.6 FPS	1.3 FPS
Unet (257x257)	7.5 FPS	6.8 FPS	7.2 FPS	6.6 FPS	4.0 FPS	3.6 FPS
PoseNet (257x257)	10.3 FPS	9.2 FPS	9.4 FPS	8.7 FPS	5.0 FPS	4.3 FPS

Asennuksen jälkeen tarkastettiin käyttäjärjestelmän, sekä C++ kääntäjän versiot, sillä aikaisemman Raspberry OS version mukana tuli 32-bittinen C++ kääntäjä (arm-linux-gnueabihf).

Komennolla `uname -a` voidaan tarkastaa käyttäjärjestelmän versio ja komennolla `gcc -v` C++ kääntäjän versio (kuva 37) (Q-engineering, n.d. b).

Kuva 37 Kuvakaappaus käytetystä 64-bittisen käyttöjärjestelmän ja kääntäjän versiosta.

```

pi@raspberrypi: ~
Tiedosto Muokkaa Välilehdet Ohje
pi@raspberrypi:~ $ uname -a
Linux raspberrypi 5.10.17-v8+ #1403 SMP PREEMPT Mon Feb 22 11:37:54 GMT 2021 aarch64
GNU/Linux
pi@raspberrypi:~ $ gcc -v
Using built-in specs.
COLLECT_GCC=gcc
COLLECT_LTO_WRAPPER=/usr/lib/gcc/aarch64-linux-gnu/8/lto-wrapper
Target: aarch64-linux-gnu
Configured with: ../src/configure -v --with-pkgversion='Debian 8.3.0-6' --with-bugurl
=file:///usr/share/doc/gcc-8/README.Bugs --enable-languages=c,ada,c++,go,d,fortran,ob
jc,obj-c++ --prefix=/usr --with-gcc-major-version-only --program-suffix=-8 --program-
prefix=aarch64-linux-gnu- --enable-shared --enable-linker-build-id --libexecdir=/usr/
lib --without-included-gettext --enable-threads=posix --libdir=/usr/lib --enable-nls
--enable-bootstrap --enable-clocale=gnu --enable-libstdcxx-debug --enable-libstdcxx-t
ime=yes --with-default-libstdcxx-abi=new --enable-gnu-unique-object --disable-libquad
math --disable-libquadmath-support --enable-plugin --enable-default-pie --with-system
-zlib --disable-libphobos --enable-multiarch --enable-fix-cortex-a53-843419 --disable
-werror --enable-checking=release --build=aarch64-linux-gnu --host=aarch64-linux-gnu
--target=aarch64-linux-gnu
Thread model: posix
gcc version 8.3.0 (Debian 8.3.0-6)
pi@raspberrypi:~ $

```

Raspberry Pi4 hankittiin 4Gt muistilla, joka on riittävyyden rajoilla. Tarpeen mukaan muistin riittävyyden takaamiseksi voi käyttää jotain muistin hallintaohjelmaa, joka siirtää väliaikaisesti harvemmin käytetyt tiedot tiedostoksi SD-muistille. Tämä lisää vapaata työmuistin määrää, mutta vastaavasti lyhentää muistikortin elinikää, koska muistikortilla on tietty määrä kirjoituskertoja, jota se kestää vikaantumatta. (Q-engineering, n.d. b)

Toinen vaihtoehto on käyttää esimerkiksi zram ohjelmaa, joka kompressoii harvemmin käytetyt tiedot zip-paketiksi ja tallentaa sen takaisin RAM muistiin. Saavutettu vapautetun muistin määrä on alkuperäisten tiedostojen koon ja pakattujen tiedostojen koon ero. Tämä on huomattavasti nopeampi mekanismi, kuin flash muistille kirjoitus. (Q-engineering, n.d. b)

Projektissa päätettiin käyttää zram -ohjelmaa, jonka avulla vapaata muistia jää vielä reilusti käytettäväksi.

Alla kuvassa 38 on kuvakaappaus resurssien käytöstä käytettäessä Yolov5 hahmontunnistusta. Näkymän saa auki komentorivin htop komennolla.

Kuva 38 Kuvakaappaus muistin käytöstä YoloV5 algoritmillä.

```

pi@raspberrypi: ~
Tiedosto Muokkaa Välilehdet Ohje

1 [|||||] [97.4%] Tasks: 66, 75 thr; 4 running
2 [|||||] [87.1%] Load average: 3.04 1.48 0.63
3 [|||||] [90.9%] Uptime: 00:22:44
4 [|||||] [90.8%]
Mem [|||||] 579M/3.66G
Swp [|||||] 0K/100.0M

PID USER PRI NI VIRT RES SHR S CPU% MEM% TIME+ Command
4085 pi 20 0 943M 239M 43972 R 343. 6.4 3:51.48 /home/pi/software/YoloV5/bin/Release/YoloV5
4086 pi 20 0 943M 239M 43972 R 87.0 6.4 0:57.66 /home/pi/software/YoloV5/bin/Release/YoloV5
4087 pi 20 0 943M 239M 43972 R 86.4 6.4 0:57.27 /home/pi/software/YoloV5/bin/Release/YoloV5
4088 pi 20 0 943M 239M 43972 S 83.1 6.4 0:55.59 /home/pi/software/YoloV5/bin/Release/YoloV5
2870 pi 20 0 727M 113M 43132 S 7.1 3.0 0:40.79 codeblocks
571 root 20 0 241M 89512 59924 S 4.5 2.3 0:40.36 /usr/lib/xorg/Xorg :0 -seat seat0 -auth /var
4128 pi 20 0 4612 3136 2348 R 1.3 0.1 0:01.07 htop
671 pi 20 0 605M 36588 25868 R 0.6 1.0 0:10.58 lxpanel --profile LXDE-pi
4106 pi 20 0 339M 32804 23752 S 0.6 0.9 0:01.29 lxterminal
4102 pi 20 0 943M 239M 43972 S 0.6 6.4 0:00.09 /home/pi/software/YoloV5/bin/Release/YoloV5
588 root 20 0 241M 89512 59924 S 0.0 2.3 0:03.27 /usr/lib/xorg/Xorg :0 -seat seat0 -auth /var
673 pi 20 0 7728 4740 4000 S 0.0 0.1 0:01.34 xscreensaver -no-splash
4101 pi 20 0 943M 239M 43972 S 0.0 6.4 0:00.08 /home/pi/software/YoloV5/bin/Release/YoloV5
607 pi 20 0 243M 14200 12356 S 0.0 0.4 0:00.58 /usr/bin/lxsession -s LXDE-pi -e LXDE
4100 pi 20 0 943M 239M 43972 S 0.0 6.4 0:00.09 /home/pi/software/YoloV5/bin/Release/YoloV5
534 root 20 0 102M 19996 10772 S 0.0 0.5 0:00.48 /usr/bin/vncserver-x11-core -service
662 pi 20 0 65404 19544 13352 S 0.0 0.5 0:01.30 openbox --config-file /home/pi/.config/openb
446 nobody 20 0 4488 2216 2012 S 0.0 0.1 0:00.99 /usr/sbin/thd --triggers /etc/triggerhappy/t
F1Help F2Setup F3Search F4Filter F5Tree F6SortBy F7Nice F8Nice F9Kill F10Quit

```

5.2 Hahmontunnistusalgoritmit

Hahmontunnistus on mittausten ja havaintojen tekemistä luonnollisista kohteista, näiden mittausten automaattista analyysiä ja kohteiden tunnistamista analyysin perusteella.

Hahmontunnistus on konenäköön ja kuvan käsittelyyn liittyvä tietokoneteknologia, joka käsittelee tietyn luokan semaattisten objektien esiintymien havaitsemista digitaalisissa kuvissa tai videoissa.

Hahmontunnistuksella on sovelluksia monilla tietokonenäköaloilla, mukaan lukien kuvanhaku ja videovalvonta. (Medium, 2020)

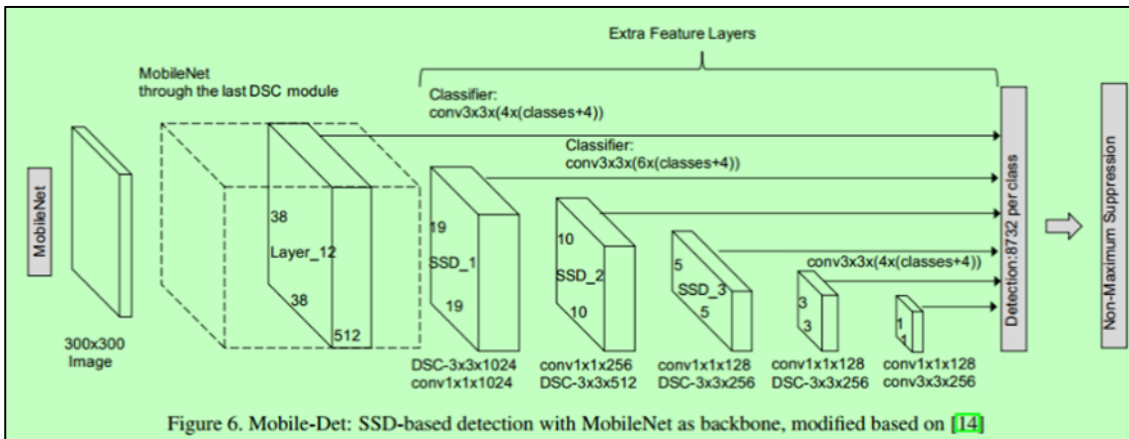
Hahmontunnistusalgoritmejä on saatavilla lukuisia toinen toistaan tarkempia tai nopeampia. Uusia versioita syntyy myös valtavalla nopeudella. Optimi vaihtoehtoa ei lähdetty hakemaan, sillä tarkoitus ei ole ollut luoda kaupallista- tai tuotantolaitetta, joka olisi suunniteltu juuri tiettyyn ympäristöön. Tämä vaatisi myös syvempää perehtymistä laskentayksikön valintaan, jos halutaan valita kohteeseen optimaalinen ratkaisu.

Raspberry Pi4:ssä testattiin kahta eri hahmontunnistusalgoritmiä: kevyesti pyörivää Tensor Flow:n MobileNet-V1 SSD, sekä raskaampaa tällä hetkellä uusinta YOLOv5 algoritmiä.

5.2.1 MobileNet-V1 SSD arkkitehtuuri

SSD-arkkitehtuuri on yksittäinen konvoluutioverkko, joka oppii ennustamaan rajapintojen sijainnit ja luokittelemaan nämä sijainnit yhdellä kertaa. SSD-verkko koostuu perusarkkitehtuurista (tässä tapauksessa MobileNet), jota seuraa useita konvoluutiokerroksia (kuva 39). (Medium, 2020)

Kuva 39 SSD mobilenet arkkitehtuuri (Medium, 2020).



SSD:tä käyttämällä meidän tarvitsee ottaa vain yksi otos havaitaksemme useita kohteita kuvassa, kun taas alueellisiin ehdotusverkkoihin (Regional Proposal Network RPN) perustuvat lähestymistavat, kuten R-CNN sarjat, jotka tarvitsevat kaksi kuvaa. Yhden alue-ehdotusten luomiseen ja toisen kunkin ehdotuksen kohteen havaitsemiseen. Siten SSD on nopeampi verrattuna kahden otoksen RPN-pohjaisiin lähestymistapoihin. (Medium, 2020)

Ensimmäinen testi suoritettiin käyttäen Tensor Flow:n MobileNet-V1 SSD mallia. Tämä hahmontunnistusalgoritmi pyöri Raspberry Pi4:ssä 22FPS nopeudella, joka olisi nopeutensa puolesta riittävä myös muuhun reaaliaikaiseen sovellukseen.

Henkilön tunnistuksen lisäksi haluttiin laskea kuvassa näkyvä henkilömäärä halutuina aikaväleinä. Tieto tallennetaan SD-muistille Data.txt tiedostoon aikaleiman kanssa. Tätä varten ohjelmaan lisättiin henkilöluokan laskuri.

Ohjelmaan lisättiin myös aliohjelma, joka tallentaa henkilömäärän, sekä aikaleiman SD-muistille tiedostoon Data.txt (kuva 40).

Kuva 40 Kuvakaappaus koodista jolla tallennetaan henkilömäärä ja aikaleima SD-muistille.

```
void saveToSD()
{
    time_t now = time(0);
    char* dt = ctime(&now);
    std::ofstream outfile;
    outfile.open("Data.txt", std::ios_base::app);
    outfile << "Persons:" << '\t' << personCount << '\t' << dt;
}
```


5.2.2 YOLO v5

YOLO ja SSD ovat molemmat Single Shot Detectoreita. Single Shot Detectors tekee molemmat yhdellä kertaa, ennustaen samanaikaisesti rajausaluetta ja luokkaa, kun se käsittelee kuvaa.

YOLO jakaa jokaisen kuvan $S \times S$ ruudukoksi ja jokainen ruudukko ennustaa N rajaa ja luotettavuutta. Luotettavuus heijastaa rajoitusalueen tarkkuutta ja sisältääkö rajoituslaatikko objektin. YOLO ennustaa myös luokittelupisteet jokaisen laatikon jokaiselle luokalle.

Eli ennustetaan yhteensä $S \times S \times N$ laatikkoa. Useimmilla näistä laatikoista on kuitenkin alhaiset luottamuspisteet, ja jos asetamme kynnyksen esimerkiksi 30 %:n luotettavuudelle, voimme poistaa suurimman osan niistä alla olevan esimerkin mukaisesti (kuva 41). (cv-tricks, n.d.)

Kuva 41 YOLO:n tapa käsitellä kuvaa (cv-tricks, n.d.).



YOLOv5 testattiin myös Raspberry Pi4:llä. Suorituskyky riittää tämän kaltaiseen mittaukseen, jossa henkilömäärä lasketaan harvakseltaan. Muissa tapauksissa YOLOv5 vaatii tehokkaampia,

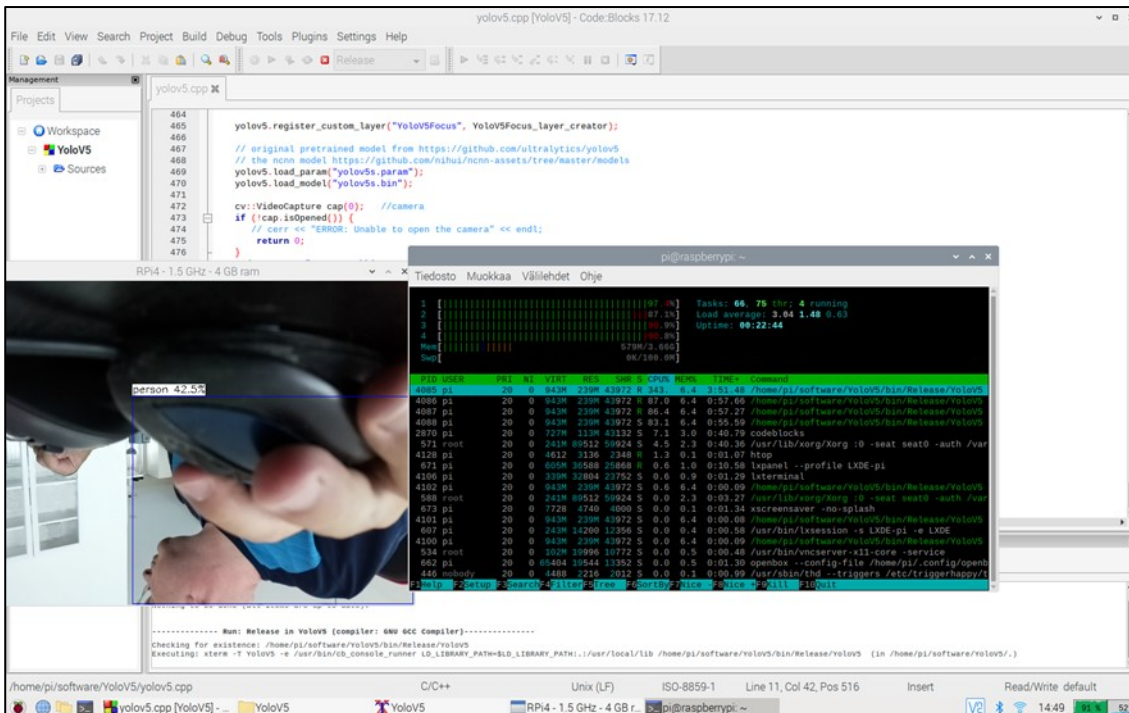
ammattimaisempia laskentayksiköitä. Käytännön tarkkuus YOLO5:lla oli selkeästi parempi. Vastaavaasti tunnistettavia objekteja on 80, kun MobileNet V1 rajoittuu kymmeneen. Kuvassa 42 on esitetty Jetson Nanon ja Raspberry Pi4:n suorituskyyvyt eri hahmontunnistusalgoritmeilla.

Kuva 42 YOLOv5 suorituskyyky Raspberry Pi4 ja Jetson Nanolla (Q-engineering, 2021b).

Model	size	objects	mAP	Jetson Nano 2015 MHz	RPi 4 64-OS 1950 MHz
NanoDet	320x320	80	20.6	28.2 FPS	13.0 FPS
YoloFastestV2	352x352	80	24.1	38.4 FPS	18.8 FPS
YoloV2	416x416	20	19.2	10.1 FPS	3.0 FPS
YoloV3	352x352 tiny	20	16.6	17.7 FPS	4.4 FPS
YoloV4	416x416 tiny	80	21.7	11.2 FPS	3.4 FPS
YoloV4	608x608 full	80	45.3	0.7 FPS	0.2 FPS
YoloV5	640x640 small	80	22.5	4.0 FPS	1.6 FPS
YoloX	416x416 nano	80	25.8	17.6 FPS	7.0 FPS
YoloX	416x416 tiny	80	32.8	8.3 FPS	2.8 FPS
YoloX	640x640 small	80	40.5	2.6 FPS	0.9 FPS

Muistin käyttö muistinhallintaa käyttäen asettui noin 580Mb tasolle (kuva 43). Käytetty 4GB version muisti on hyvinkin riittävä. Lämpötila asettui jäähdyttimillä varustettuna 50-55 asteen paikkeille, joka on hyvä taso kestävyydelle.

Kuva 43 Kuvakaappaus Raspberry Pi4 YOLOv5 resurssien käytöstä. Huomiona että tästä kameran kuvasta pystyttiin tunnistamaan henkilö.



Lämpötilan ylittäessä tehdasasetuksilla 82 °C, Raspberry Pi pudottaa kellotaajuutta automaattisesti lämpötilan alentamiseksi. Jäähdytymisen jälkeen kellotaajuus palautuu takaisin asetettuun tasoon. Kuvassa 44 on esitetty Raspberry Pi4:n maksimilämpötiloista, sekä eri suorituskykyasetuksista. (Q-engineering, 2021c)

Kuva 44 Taulukko Raspberry Pi maksimi lämpötiloista, sekä eri suorituskykyasetuksista (Q-engineering, 2021c).

Clock (MHz)	Overvoltage	V _{core}	Max temp. (°C °F)	Power (Watt)	Preformance increase	Remarks
0	0	0.8625		1.5		RPI 4 shut down
200	0	0.8625		1.75		RPI 4 min working clock
600	0	0.8625		2.8		RPI 4 running idle
1500	0	0.8625	82 180	7		Factory settings
1600	1	0.8875	80 176	7.6	6.6 %	
1700	2	0.9125	78 172	8.3	13.3 %	
1800	3	0.9375	77 170	8.9	20 %	
1900	4	0.9625	75 167	9.5	26.6 %	
2000	6	1.0125	72 162	11	33.3 %	
2100	6	1.0125	72 162	11	40 %	
	7	1.0375	56 132	11.7		no improvement
	8	1.0625	50 122	12.3		no improvement

5.2.3 COCO dataset

COCO on laajamittainen objektien tunnistus-, segmentointi ja tekstitystietojoukko. COCO datasettiä käytettiin mallien opetuksessa. Datasetsi sisältää 330K kuvaa, sekä 80 objektiluokkaa, esimerkiksi henkilö, kissa, koira jne. (Cocodataset, n.d.)

5.3 Laitteen testaus

Rakennetun laitteen testaus jouduttiin rajoittamaan kotioloihin pääasiassa koronasta johtuvien ongelmien vuoksi. Testausta oli suunniteltu Citymarket-yrittäjän kanssa, sekä Linnan Kehityksen tiloissa, mutta yllättävien haasteiden vuoksi testausta ei saatu toteutettua uudessa ympäristössä. Laitetta kuitenkin testattiin kotioloissa mittaamaan huoneessa olleiden henkilöiden määrää. Laskurin laskema henkilömäärä tulostettiin näytölle, josta pystyi seuraamaan laskurin kykyä tunnistaa henkilöitä. Laitteen tarkkuus ylitti odotukset, sillä kuvassa ei tarvitse näkyä kokonaista ihmistä, kun laskuri pystyi jo tunnistamaan henkilön, eikä vääriä positiivisia esiintynyt. Osittain

näkyvillä olevien henkilöiden tunnistus olisi se käytännön haaste henkilömäärien mittauksessa, kun osa henkilöistä on väkisinkin osittain katveessa. Tulos oli kuitenkin tältä osin lupaava.

6 Yhteenveto

Työssä tutkittiin yleisesti käytettyjä henkilölaskureita jotka perustuvat usein portti-tyyppisiin mittauksiin esim. mittauksiin oviaukoilla. Näitä laskimia on kehitetty sisällyttämällä esim. wifi-pohjaisia laskureita. Nämä sisältävät monia eri heikouksia paikan ja määrän mittaamiseksi etenkin avoimissa tiloissa, joissa on useampia kulkureittejä.

Projektissa tavoitteena oli rakentaa laskuri, jolla pystytään mittaamaan henkilömäärä avoimessa tilassa, esimerkiksi kaupan hedelmäosastolla tai vastaavassa tilassa, jossa ei ole luonnollisia portteja henkilöiden kulkureiteillä. Tältä pohjalta tutkittiin konenäköön pohjautuvaa laskuria. Etenkin tutkimuskäytössä laskentayksikön tulee asennuksen joustavuuden ja kustannuksen vuoksi olla kameran yhteydessä, jolloin vaihtoehdot ovat hieman rajoittuneempia.

Vastaava kehitystyö laskurin kehittämiseksi olisi helpompaa esim Nvidian tai Googlen laitteilla tarjoten samalla enemmän suorituskykyä. Tiukan budjetin vuoksi, sekä mahdollisuuteen hyödyntää käytettyjä laitteita muuhun käyttöön jatkossa, päädyttiin testaamaan Raspberry Pi4:sta, joka suoriutui tarpeeseen nähden hyvin tarjoten kaiken tarvittavan tiedon. Käytännön testaus jäi vielä kevyeksi, mutta saimme kokemusta ja näyttöä siihen, että tällainen vapaasti sijoitettava dataa keräävä laskuri pystytään luomaan.

IP-kameroiden ja verkkolaitteiden avulla voidaan kattaa myös suurempia alueita, sekä siirtää data verkon kautta haluttuun palveluun. Tässä projektissa data tallennettiin paikallisesti SD-muistille.

Työssä käytetyn kokoonpanon avulla voidaan projektinomaisesti tutkia henkilömääriä hyvin pienellä investoinnilla ja mahdollinen laitteen monistaminen tapahtuisi SD-muistin kopiolla. Laitteen koko on myös huomaamattoman pieni. Toki laite on harraste- tai protoilutasoa, mutta toiminnallisuus on sama kuin vartavasten käyttöön suunnitelluilla laitteilla.

HAMKin opintotarjonnassa ei ole tekoäly- tai koneoppimiskursseja, joten osaamista joutui hankkimaan itsenäisesti muista oppilaitoksista. Oppimiskokemuksena projekti oli kokonaisuudessaan hyvä luoden hyvän pohjan jatkokehitykselle.

Lähteet

Arrow. (n.d. a). *Jetson Nano*. Haettu osoitteesta 5.6.2022

<https://www.arrow.com/en/products/945-13541-0000-000/nvidia>

Arrow. (n.d. b). *Jetson AGX Xavier Developer Kit*. Haettu osoitteesta 5.6.2022

<https://www.arrow.com/en/products/945-82972-0045-000/nvidia>

Cisco Systems. (n.d.). *Location Analytics*. Haettu osoitteesta 5.6.2022

https://meraki.cisco.com/lib/pdf/meraki_datasheet_location_analytics.pdf

Cocodataset. (n.d.). *What is COCO?* Haettu osoitteesta 5.6.2022 <https://cocodataset.org/#home>

cv-tricks. (n.d.). *Guide to Object Detection using Deep Learning: Faster R-CNN, YOLO, SSD*. Haettu osoitteesta 5.6.2022 <https://cv-tricks.com/object-detection/faster-r-cnn-yolo-ssd>

Dahuasecurity. (n.d.). *IPC-HFW2231S-S-S2*. Haettu osoitteesta 5.6.2022

<https://www.dahuasecurity.com/products/All-Products/Network-Cameras/Lite-Series/2-MP/IPC-HFW2231S-S-S2>

Developers, N. (n.d. a). *Jetson Nano*. Haettu osoitteesta 5.6.2022

<https://developer.nvidia.com/embedded/jetson-nano>

Developers, N. (n.d. b). *Jetson Benchmarks*. Haettu osoitteesta 5.6.2022

<https://developer.nvidia.com/embedded/jetson-benchmarks>

FootFallCam. (2017a). *Evolution of People Counters*. Haettu osoitteesta 5.6.2022

<https://www.footfallcam.com/blog/2017/12/223-evolution-of-people-counters>

FootFallCam. (2017b). *Wifi Counting Solution*. Haettu osoitteesta 5.6.2022

<https://www.footfallcam.com/Product/WifiCountingSolution>

Jiglabs. (n.d.). *Sanovo revolutionize egg inspection*. Haettu osoitteesta 5.6.2022

<https://jiglabs.io/product>

Logitech. (n.d.). *C902e-yritysverkkokamera*. Haettu osoitteesta 5.6.2022

<https://www.logitech.com/fi-fi/products/webcams/c920e-business-webcam.960-001360.html?crd=1690#specs>

Medium. (2020). *SSD MobileNet Architecture*. Haettu osoitteesta 5.6.2022

<https://medium.com/@techmayank2000/object-detection-using-ssd-mobilenetv2-using-tensorflow-api-can-detect-any-single-class-from-31a31bbd0691>

NVIDIA. (n.d.). *Jetson AGX Xavier Developer Kit*. Haettu osoitteesta 5.6.2022

<https://www.nvidia.com/fi-fi/autonomous-machines/jetson-store/#jetson-agx-xavier>

- Opetushallitus. (2004). *puutuoteteollisuus/automaatio/konenako*. Haettu osoitteesta 5.6.2022
<http://www03.edu.fi/oppimateriaalit/puutuoteteollisuus/automaatio/konenako/index.html>
- Q-engineering. (2021a). *YoloV5 Raspberry Pi 4*. Haettu osoitteesta 5.6.2022
<https://github.com/Qengineering/YoloV5-ncnn-Jetson-Nano>
- Q-engineering. (2021b). *YoloV5-ncnn-Raspberry-Pi-4*. Haettu osoitteesta 5.6.2022
<https://github.com/Qengineering/YoloV5-ncnn-Raspberry-Pi-4>
- Q-engineering. (2021c). *Safe overclocking of the Raspberry Pi 4 to 2 GHz*. Haettu osoitteesta 5.6.2022
<https://qengineering.eu/overclocking-the-raspberry-pi-4.html>
- Q-engineering. (n.d. a). *Install TensorFlow Lite 2.4.0 on Raspberry 64 OS*. Haettu osoitteesta 5.6.2022
<https://qengineering.eu/install-tensorflow-2-lite-on-raspberry-64-os.html>
- Q-engineering. (n.d. b). *Install 64 bit OS on Raspberry Pi 4 + USB boot*. Haettu osoitteesta 5.6.2022
<https://qengineering.eu/install-raspberry-64-os.html>
- Radioduo. (n.d.). *KOTELO: TIETOKONEELLE - JETSON-NANO-4GB*. Haettu osoitteesta 5.6.2022
https://www.radioduo.fi/kotelo%3A-tietokoneelle--jetson-nano-4gb-v2--teras--musta--x%3A-85mm/p/OKDO-2237610/?gclid=CjwKCAjwkMeUBhBuEiwA4hpgEC93GVre99qmBeWvqDML-uBXG5J8apMML4f-a1joXMn9QnUp7t9xwBoCe5EQAvD_BwE
- Raspberry Pi Foundation. (n.d.). *Raspberry Pi 4*. Haettu osoitteesta 5.6.2022
<https://www.raspberrypi.org/products/raspberry-pi-4-model-b>
- Raspberry Pi Trading. (2019). *Raspberry Pi 4 specs and benchmarks*. Haettu osoitteesta 5.6.2022
<https://magpi.raspberrypi.org/articles/raspberry-pi-4-specs-benchmarks>
- Raspberrypi. (n.d. a). *Camera Module V2*. Haettu osoitteesta 5.6.2022
<https://www.raspberrypi.org/products/camera-module-v2>
- Raspberrypi. (n.d. b). *Raspberry Pi High Quality Camera*. Haettu osoitteesta 5.6.2022
<https://www.raspberrypi.com/products/raspberry-pi-high-quality-camera>
- Research and Markets. (2021). *Machine Vision Market*. Haettu osoitteesta 5.6.2022
<https://www.marketsandmarkets.com/Market-Reports/industrial-machine-vision-market-234246734.html>
- SAS Institute. (n.d.). *History of computer vision*. Haettu osoitteesta 5.6.2022
https://www.sas.com/en_au/insights/analytics/computer-vision.html

- Suomenturvatuote. (n.d. a). *Dahua IPC-HFW2231S-S-S2 Bullet Valvontakamera*. Haettu osoitteesta 5.6.2022 <https://suomenturvatuote.fi/product/215/dahua-ipc-hfw2231s-s-s2-bullet-valvontakamera>
- Suomenturvatuote. (n.d. b). *Dahua PFS3110-8P-96 PoE- kytkin sisä- ja ulkotiloihin*. Haettu osoitteesta 5.6.2022 <https://suomenturvatuote.fi/product/233/dahua-pfs3110-8p-96-poe-kytkin-sisa--ja-ulkotiloihin>
- Suomenturvatuote. (n.d. c). *Teltonika RUT240 4G LTE Reititin*. Haettu osoitteesta 5.6.2022 <https://suomenturvatuote.fi/product/287/teltonika-rut240-4g-lte-reititin>
- Terabee. (n.d.). *People Counting*. Haettu osoitteesta 5.6.2022 <https://www.terabee.com/products/people-counting>
- Towards Data Science inc. (2019). *Everything You Ever Wanted To Know About Computer Vision*. Haettu osoitteesta 5.6.2022 <https://towardsdatascience.com/everything-you-ever-wanted-to-know-about-computer-vision-heres-a-look-why-it-s-so-awesome-e8a58dfb641e>
- Towardsdatascience. (2020a). *mAP (mean Average Precision) might confuse you!* Haettu osoitteesta 5.6.2022 <https://towardsdatascience.com/map-mean-average-precision-might-confuse-you-5956f1bfa9e2>
- Towardsdatascience. (2020b). *Increase Frame Per Second (FPS) rate in the Custom Object Detection Step by step*. Haettu osoitteesta 5.6.2022 <https://towardsdatascience.com/no-gpu-for-your-production-server-a20616bb04bd>
- Verkkokauppa.com. (n.d.). *Raspberry Pi 4 model B 4 Gt - yhden piirilevyn tietokone*. Haettu osoitteesta 5.6.2022 <https://www.verkkokauppa.com/fi/product/561778/Raspberry-Pi-4-model-B-4-Gt-yhden-piirilevyn-tietokone>
- Viso.ai. (n.d.). *Computer Vision In Manufacturing – The 10 Most Popular Applications*. Haettu osoitteesta 5.6.2022 <https://viso.ai/applications/computer-vision-in-manufacturing/>
- Wikipedia. (4.4.2022). *Raspberry Pi*. Wikipedia-artikkeli https://fi.wikipedia.org/w/index.php?title=Raspberry_Pi&oldid=20402502
- Windmill Software. (2019). *People Counting: Eight Technologies to Measure Footfall*. Haettu osoitteesta 5.6.2022 <https://www.windmill.co.uk/footfall-technology.html>